

Южная математическая смена 2018 в «Сириусе»
Курс «Машинное обучение»

Лекция первая

«Введение в машинное обучение»¹

14 ноября, 2018

¹Автор: Мурат Апишев (mel-lain@yandex.ru)

Ваши преподаватели



- ▶ **Мурат Апишев**
- ▶ **ВМК МГУ**, ФКН ВШЭ, ФУПМ МФТИ, ШАД
- ▶ Яндекс.Дзен, ЛМИ МФТИ, Яндекс.Поиск



- ▶ **Надежда Зуева**
- ▶ **ФИВТ МФТИ**, ФПМИ МФТИ
- ▶ iPavlov, АBBYU



- ▶ **Татьяна Гайнцева**
- ▶ **ФИВТ МФТИ**, **ШАД**, Сбербанк
- ▶ LAMBDA ВШЭ


Что такое машинное обучение

Машинное обучение (machine learning, ML) – класс методов искусственного интеллекта, характерной чертой которых является не прямое решение задачи, а обучение в процессе применения решений множества сходных задач

Что это означает:

- ▶ Есть некоторая задача, например
 - ▶ поиск текстов
 - ▶ распознавание изображений
 - ▶ прогноз цен на акции
 - ▶ написание стихов
- ▶ Человек умеет решать задачу хорошо, но делает это очень медленно
- ▶ Хочется на примере человека научить компьютер решать эти задачи намного быстрее с небольшой потерей качества

Машинное обучение и анализ данных




Пример: поисковые системы

- ▶ Поисковые системы прочно вошли в нашу жизнь, мы пользуемся ими каждый день
- ▶ Раньше поиск был ограничен текстами
- ▶ В последние годы развитие нейронных сетей позволило создать поиск по изображениям
- ▶ Поиск – сложная система, в которой решается несколько больших задач машинного обучения



Пример: рекомендации

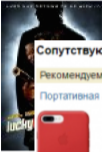
Recommended for you



Сопутствующие товары

Рекомендуем Чехлы/сумки/рюкзаки

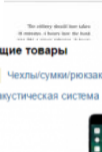
Портативная акустическая система



2 979 ₽

Apple Leather Case чехол для iPhone 7 Plus.

В корзину




2 449 ₽

Дерра 3D з-стекло для


В корзину

Рекомендуем также


← Prev



New Album Releases




Original Album Classics
Paul Simon
[Buy at Amazon \(Search\)](#)




What Could Have Been Love
Aerosmith
[Buy at Amazon \(Search\)](#)

[See all new release recommendations](#)


Music




Машина Времени
Similar to: Машина времени, Nautilus Pompilius, Чайф



Леонид Фёдоров
Similar to: ВЫХОД, Аукцыон, Веня Д'ркин



Артерия
Similar to: Чёрный Обелиск, Kruger, Эпидемия



Потаня
Similar to: Тол Мириам, Тэм, Йовин

[Play your Recommendations](#)

[See/edit all your music recommendations](#)

Events in Seattle, United States (change location)

Пример: машинный перевод

- ▶ Учить компьютер переводить тексты вместо человека пробовали ещё с середины прошлого века
- ▶ До недавнего времени результаты были не слишком хороши, даже переводчики Google и Yandex делали некачественные переводы
- ▶ Машинный перевод оказался одной из областей анализа текстов, в которых развитие нейронных сетей привело к качественному прорыву



Пример: прогнозирование

Прогнозировать можно пытаться буквально всё, что угодно:

- ▶ Выдавать кредит или нет?
- ▶ Отзыв на фильм хороший или нет?
- ▶ Чем может быть болен этот человек?
- ▶ Как разложить эти песни по жанрам?
- ▶ Какая модель автомобиля изображена на фотографии?
- ▶ Как будет меняться цена портфеля акций на бирже?
- ▶ Что сейчас произнёс этот человек?

В широком смысле прогнозирование включает в себя и поисковые системы, и рекомендации

Исторические вехи машинного обучения

- ▶ Математический аппарат, который лёг в основу машинного обучения, стал появляться ещё в 18-м веке
- ▶ Искусственный интеллект и распознавание образов образов появились вместе с первыми компьютерами
- ▶ **1943** – модель искусственного нейрона МакКаллока-Питтса
- ▶ **1960** – первый нейрокомпьютер (двуслойная сеть)
- ▶ **1970-е** – генетические алгоритмы
- ▶ **1977** – восстановление смеси распределений, EM-алгоритм
- ▶ **1963, 1992** – метод опорных векторов (SVM)

Современное положение дел

- ▶ **1982** – рекуррентные нейронные сети (RNN)
- ▶ **1998** – свёрточные нейронные сети (CNN)
- ▶ **1999** – градиентный бустинг
- ▶ **2001** – случайный лес
- ▶ **1986** – метод обратного распространения ошибок (BackProp)
- ▶ **1965-2007** – глубокие нейронные сети
- ▶ **Последние 10 лет: бум нейронных сетей**
 - ▶ Обучение нейронных сетей перешло с процессоров на видеокарты
 - ▶ Сбор и использование больших массивов данных (Big Data)
 - ▶ Появилось большое количество разнообразных архитектур (Resnet, GAN, Transformer, VAE)
 - ▶ Вместе с нейросетями активно развивается *обучение с подкреплением* – основная надежда робототехники

Что требуется от хорошего аналитика

1. Владением математическим аппаратом:

- ▶ линейная алгебра и аналитическая геометрия
- ▶ математический анализ
- ▶ теория вероятности и математическая статистика
- ▶ методы оптимизации
- ▶ алгоритмы и структуры данных

2. Знание предметной области, например:

- ▶ анализ данных в медицине/фармацевтике требует некоторого владения химией и биологией
- ▶ для анализа текстов (NLP) нужно разобраться в грамматике и лингвистике

3. Умение программировать:

Python/Matlab/R/Julia/C++/Java/C#/Scala/Go

Математические основы

- ▶ Указанные выше области математики читаются в университетах в течение нескольких лет
- ▶ Тем не менее, для практического использования ML обычно хватает самых базовых понятий и алгоритмов
- ▶ К таким относятся:
 - ▶ вектор и матрица
 - ▶ матричные операции
 - ▶ определение и смысл производной
 - ▶ градиент и градиентный спуск
 - ▶ вероятность и распределение вероятности
 - ▶ выборка и её статистики
- ▶ Как только разберёмся с ними, попробуем формально поставить задачи машинного обучения

Вектор

- ▶ Вектор – это величина, характеризующаяся величиной и направлением
- ▶ Вектор – это направленный отрезок
- ▶ Вектор – это элемент векторного (линейного) пространства
- ▶ Вектор – это массив из n элементов (в случае конечномерного пространства)

Все эти определения верны и обозначают одно и то же!

Проще всего представить вектор a как массив вещественных чисел длины n , над которым определены операции

- ▶ по-элементного сложения: $a + b = c$, $c_i = a_i + b_i$, $i = \overline{1, n}$
- ▶ умножения на число (скаляр): $a * k = d$, $d_i = a_i * k$, $i = \overline{1, n}$, $k \in \mathbb{R}$

Связь с геометрией

- ▶ Вектор в геометрии – направленный отрезок
- ▶ Без ограничения общности можно считать, что он исходит из точки начала координат
- ▶ Тогда, в случае плоскости, он определяется двумя числами-координатами, в случае трёхмерного пространства – тремя
- ▶ Сложение векторов в геометрии идентично описанной выше операции по-элементного сложения



Скалярное произведение

- ▶ *Скалярное произведение векторов* – ещё одно фундаментальное понятие линейной алгебры
- ▶ Обычно определяется в школьной геометрии следующим образом

$$\langle a, b \rangle = |a| \cdot |b| \cdot \cos \angle (a, b)$$

- ▶ $|\cdot|$ – это *норма вектора*, можно понимать её как длину вектора. Нормы бывают разные, наиболее известная – евклидова

$$|a| = \sqrt{\sum_{i=1}^n a_i^2}$$

- ▶ В алгебраической форме СП выглядит так

$$\langle a, b \rangle = \sum_{i=1}^n a_i \cdot b_i$$

Метрика

- ▶ *Метрика* – функция $d(x, y)$, удовлетворяющая следующим аксиомам:
 1. $d(x, y) = 0 \Leftrightarrow x = y$
 2. $d(x, y) = d(y, x)$
 3. $d(x, z) \leq d(x, y) + d(y, z)$ – *неравенство треугольника*
- ▶ Метрика – это расстояние между двумя объектами: числами, векторами, матрицами
- ▶ Примеры:
 - ▶ $d(x, y) = 1$ при $x \neq y$, иначе – 0
 - ▶ $d(x, y) = |x - y|$, $x, y \in \mathbb{R}$
 - ▶ $d(x, y) = \sum_{i=1}^n |x_i - y_i|$, $x, y \in \mathbb{R}^n$
 - ▶ $d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$, $x, y \in \mathbb{R}^n$ – *евклидово расстояние*

Матрица

Матрица (над полем \mathbb{R}) — математический объект, записываемый в виде прямоугольной таблицы элементов из \mathbb{R} , которая представляет собой совокупность строк и столбцов, на пересечении которых находятся эти элементы

Вектор = одномерная матрица! Но важно, столбец или строка

Это матрица - строка	Это матрица - столбец	Это квадратная матрица третьего порядка
$\begin{bmatrix} 4 & 53 & 47 \end{bmatrix}$	$\begin{bmatrix} 62 \\ 2 \\ 10 \\ 48 \end{bmatrix}$	$\begin{bmatrix} 6 & 4 & 67 \\ 2 & 34 & 7 \\ 7 & 9 & 10 \end{bmatrix}$
Это диагональная матрица	Это единичная матрица	Это нулевая матрица
$\begin{bmatrix} 6 & 0 & 0 \\ 0 & 34 & 0 \\ 0 & 0 & 10 \end{bmatrix}$	$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}$

Основные матричные операции

- ▶ **Транспонирование:** A^T – матрица «поворачивается» вокруг главной диагонали на 180 (строки становятся столбцами)
- ▶ **Обращение:** A^{-1} – матрица, умножение на которую матрицы A даст единичную матрицу (определена только для подкласса квадратных матриц)
- ▶ **Умножение на число** – аналогично векторам
- ▶ **Матричное умножение** – если есть две матрицы $A \in \mathbb{R}^{n \times m}$ и $B \in \mathbb{R}^{m \times \ell}$, то их произведение будет матрицей $C \in \mathbb{R}^{n \times \ell}$, элементы которой определяются выражением

$$c_{ij} = \sum_{k=1}^m a_{ik} \cdot b_{kj}$$

Произведение матриц

$$\begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix} \times \begin{bmatrix} a & c \\ b & d \end{bmatrix} = \begin{bmatrix} 1a + 2b & 1c + 2d \\ 3a + 4b & 3c + 4d \end{bmatrix}$$


Перемножаться могут любые матрицы, у которых совпадает *промежуточная размерность* – число столбцов у первой и число строк у второй

Производная функции

- ▶ Пусть функция f определена и гладка в некоторой окрестности точки x
- ▶ Тогда производной $f'(x)$ функции f в точке x называется величина

$$f'(x) = \frac{\Delta f}{\Delta x}, \quad \Delta x \rightarrow 0$$


- ▶ Здесь Δx означает длину очень маленького шага от точки x
- ▶ Δy показывает, насколько сильно изменилось значение функции f при таком шаге аргумента



Смысл производной

- ▶ Производная характеризует скорость роста функции в точке:
 - ▶ $f'(x) = 0$ – функция в точке идёт параллельно оси аргумента
 - ▶ $f'(x) > 0$ – функция растёт, чем выше значение, тем быстрее
 - ▶ $f'(x) < 0$ – функция убывает, чем выше модуль значения, тем быстрее
- ▶ В уравнении прямой $y = k \cdot x + b$ величина k называется *угловым коэффициентом*
- ▶ С геометрической точки зрения, производная в точке x – угловой коэффициент касательной к графику f в x
- ▶ Изменение знака производной означает изменение характера монотонности функции (до изменения возрастала, после – стала убывать)

Взаимоотношения функции и её производной



Нули производной соответствуют точкам, подозрительным на экстремум.

[Ссылка на источник картинки](#)

Правила дифференцирования

Дифференцирование функции – процесс вычисления производной. Из определения производной в выведены следующие правила дифференцирования:

- ▶ $f(x) = C \Rightarrow f'(x) = 0$
- ▶ $f(x) = x^\alpha \Rightarrow f'(x) = \alpha x^{\alpha-1}$
- ▶ $f(x) = a^x \Rightarrow f'(x) = a^x \ln a$
- ▶ $f(x) = \log_a x \Rightarrow f'(x) = \frac{1}{x \ln a}$
- ▶ $f(x) = e^x \Rightarrow f'(x) = e^x$
- ▶ $f(x) = \operatorname{tg} x \Rightarrow f'(x) = \frac{1}{\cos^2 x}$
- ▶ $f(x) = \sin x \Rightarrow f'(x) = \cos x$
- ▶ $f(x) = \cos x \Rightarrow f'(x) = -\sin x$
- ▶ $(f + g)' = f' + g'$
- ▶ $(Cf)' = Cf'$
- ▶ $(fg)' = f'g + fg'$
- ▶ $\left(\frac{f}{g}\right)' = \frac{f'g - fg'}{g^2}, \quad g \neq 0$
- ▶ $(f(g(x)))' = f'(g(x))g'(x)$

Частная производная

- ▶ *Частная производная* – обобщение понятия производной на функции многих переменных
- ▶ Берётся по одной из переменных, равна отношению прироста функции к бесконечно малому приросту этой переменной
- ▶ Допустим, функция – скорость автомобиля s , которая зависит от объёма двигателя c и массы корпуса m
- ▶ Зафиксируем объём двигателя и увеличим массу корпуса
- ▶ Измерим, насколько поменялась скорость при таком изменении
- ▶ Посчитаем отношение приростов, устремив изменение массы к 0
- ▶ Получим частную производную скорости по массе корпуса:

$$\frac{\partial s}{\partial m} = \lim_{\Delta m \rightarrow 0} \frac{s(c, m + \Delta m) - s(c, m)}{\Delta m}$$


Градиент функции

- ▶ *Градиентом* функции, зависящей от n переменных, называется вектор её частных производных по этим переменным:

$$f(x, y, z) \Rightarrow \nabla f = \left(\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y}, \frac{\partial f}{\partial z} \right)$$

- ▶ Вектор градиента в каждой точке показывает направление наибольшего роста функции
- ▶ Точка является *локальным максимумом* функции, если существует такая её окрестность, где функция везде меньше, чем в этой точке
- ▶ *Локальный минимум* определяется аналогично
- ▶ Точки максимума/минимума называются *экстремумами*
- ▶ Градиент позволяет искать локальные экстремумы функции

Визуализация градиента 2D функции



Оптимизация функции

- ▶ Поиск экстремумов функции называется её *оптимизацией*. Обычно ищут минимум:

$$f(x) \rightarrow \min_x$$

- ▶ x может быть числом, может быть вектором или матрицей
- ▶ Для максимизации достаточно найти минимум $-f(x)$
- ▶ В начале поиска фиксируется некоторая точка x_0
- ▶ Дальше из этой точки нужно выбрать следующую точку, которая будет ближе к точке экстремума, которую мы ищем
- ▶ Существуют различные стратегии того, как делать эти шаги
- ▶ Разные алгоритмы имеют разные оценки скорости достижения какого-нибудь локального экстремума с точки зрения числа шагов и сложности их вычисления


Градиентный спуск

- ▶ *Метод градиентного спуска* – один из наиболее простых алгоритмов поиска локального экстремума заданной дифференцируемой функции f
- ▶ **Идея:** будем двигаться в направлении наибольшего убывания функции, которое задаётся антиградиентом $-\nabla f$
- ▶ На каждом шаге будем искать новую точку по предыдущей исходя из выражения

$$x^{i+1} = x^i - \lambda^i \nabla f(x^i)$$

- ▶ Выбор λ^i сильно влияет на качество и время работы алгоритма
- ▶ Слишком маленькое – будем двигаться медленно, слишком большое – можем «проскочить» узкий минимум
- ▶ Разные стратегии выбора λ^i определяют разные методы оптимизации

Градиентный спуск



На каждом шаге смещаемся в точку, которая сейчас кажется оптимальной

Вероятность

- ▶ *Вероятность* – численная мера возможности наступления некоторого события
- ▶ Существуют различные определения вероятности
- ▶ Рассмотрим частотное определение: вероятность наступления события A из некоторого (потенциально бесконечного) множества событий определяется как:

$$p(A) = \lim_{n \rightarrow \infty} \frac{n_a}{n},$$

где n – общее число испытаний, n_a – число раз, когда в испытании наблюдалось событие A

- ▶ Самый простой пример: подбрасывание монетки (два возможных события)

Вероятность

- ▶ Вероятность изменяется от 0 до 1 включительно
- ▶ Если у нас есть совокупность всевозможных событий X , то $p(X) = 1$
- ▶ Вероятность невозможного события $p(\emptyset) = 0$
- ▶ *Случайная величина* – величина, значения которой представляют собой исходы случайного события
- ▶ Исходы бросков монеты – это случайная величина
- ▶ Эта величина – *дискретная*, потому что множество исходов состоит из отдельных объектов (орёл/решка)
- ▶ Случайная величина может быть *непрерывной* – например, рост случайного человека (ось роста)

Вероятностное распределение

- ▶ Очевидно, что среди всех возможных ростов людей какие-то встречаются часто, какие-то – реже
- ▶ *Вероятностное распределение* – это закон, описывающий область значений случайной величины и вероятности их появления
- ▶ Распределение можно задавать через *функцию распределения* и
 - ▶ *закон распределения* – для дискретного распределения
 - ▶ *плотность* – для непрерывного
- ▶ Разберёмся сперва с дискретной. Пусть мы измеряем число людей с ростом 140 см, 150 см, ..., 220 см
- ▶ Пусть по медицинской статистике получается на 1000 человек:
 1. 140 см: 0.03 от общего числа
 2. 150 см: 0.07 от общего числа
 3. ...
 4. 220 см: 0.02 от общего числа
- ▶ **Это и есть закон распределения – у какого исхода какая вероятность**

Нормальное распределение

- ▶ *Нормальное (гауссовское) распределение* – самое важное и часто используемое распределение в любой прикладной области


У него есть два параметра – математическое ожидание μ и среднеквадратичное отклонение σ , функция плотности имеет вид

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

μ говорит о том, где у графика плотности «середина»

А σ – насколько далеко можно уйти от μ

- ▶ Проще всего представить, что мы хотим генерировать случайные числа (*сэмплирование*)
- ▶ Тогда график плотности определяет то, в каких диапазонах и с какой вероятностью мы будем получать числа



Задача обучения по прецедентам

- ▶ *Обучение по прецедентам = обучение с учителем*
- ▶ Есть множество объектов X и множество ответов Y
- ▶ Также есть неизвестная функция y , которая каждому элементу X ставит в соответствие какой-то элемент y
- ▶ **Пример:** X – фотографии автомобилей, Y – марки автомобилей, y – соответствие между фотографией авто и его маркой
- ▶ В задаче обучения с учителем имеем *обучающую выборку* $x_1, \dots, x_\ell \in X$, для каждого объекта которой известен правильный ответ $y_i = y(x_i)$
- ▶ Цель: построить на основе обучающей выборки алгоритм $a(x)$, который будет как можно лучше приближать функцию y на всём множестве X

Признаковое описание объекта

- ▶ **Вопрос:** а что такое объект в X ?
- ▶ Каждый объект характеризуется своим *признаковым описанием*
- ▶ *Признак* – это некоторая функция $f_j(x)$, которая принимает на данном объекте какое-то значение
- ▶ **Пример:** объект – человек, признаки – температура, рост, пол, вес, цвет волос и т.д.
- ▶ Признаковое описание – это совокупность признаков, которые мы используем в данной задаче (для медицинской диагностики вес важен, а литературные предпочтения – не очень)
- ▶ В зависимости от своей области значений, признаки бывают
 1. бинарными (пол: мужской/женский)
 2. категориальными (цвет волос: чёрный/каштановый/красный)
 3. порядковыми (оценка за экзамен: 1/2/3/4/5)
 4. количественными (вес: R)

Признаковое описание объекта

- ▶ Для решения задач машинного обучения объект реального мира представляется в виде значений набора признаков f_1, \dots, f_n
- ▶ Тогда обучающая выборка $\{x_i\}_{i=1}^{\ell}$ описывается матрицей F

$$F = \begin{bmatrix} f_1(x_1) & \dots & f_n(x_1) \\ \vdots & \vdots & \vdots \\ f_1(x_\ell) & \dots & f_n(x_\ell) \end{bmatrix}$$

- ▶ Эта матрица состоит только из чисел, если есть категориальные признаки, их надо превратить в числовые
- ▶ Самый простой вариант – заменить на несколько бинарных:
 - ▶ **было:** один признак «цвет волос» со значениями «чёрный», «каштановый», «красный»
 - ▶ **стало:** три признака «цвет волос чёрный», «цвет волос каштановый», «цвет волос красный» со значениями 0 и 1

Типы задач

В зависимости от типа множества ответов Y выделяют различные типы задач обучения с учителем:


- ▶ Задачи классификации:
 - ▶ $Y = \{0, 1\}$ – бинарная (товар хороший или плохой?)
 - ▶ $Y = \{1, \dots, M\}$ – многоклассовая без пересечений классов (какая марка у этого автомобиля?)
 - ▶ $Y = \{0, 1\}^M$ – многоклассовая с пересечением – каждый объект может относиться к нескольким классам (какие жанры у этого фильма?)
- ▶ Задачи регрессии:
 - ▶ $Y = \mathbb{R}$ (какой рост у этого человека?)
- ▶ Задачи ранжирования:
 - ▶ Y – конечное упорядоченное множество (как эти веб-страницы упорядочены по релевантности этому поисковому запросу?)

Этапы решения задачи обучения с учителем

- ▶ Поделим нашу выборку на две части: на *обучающую* и *тестовую*
- ▶ Первая нужна для того, чтобы на ней обучить модель
- ▶ Вторая – чтобы проверить качество работы этой модели
- ▶ Проверять качество работы на обучающей выборке нельзя – можно получить *переобучение*
- ▶ Это ситуация, когда модель слишком сильно подстроилась под данные обучения и не умеет никак свои знания обобщать
- ▶ Рассмотрим на примере задачи регрессии – пытаемся предсказывать значения неизвестной функции одного аргумента по нескольким точкам

Переобучение и недообучение

- ▶ Наша модель – функция-многочлен
- ▶ У модели есть *параметры* – то, что обучается, в нашем случае, это коэффициенты многочлена
- ▶ Ещё у модели есть *гиперпараметры* – то, что мы выбираем заранее, здесь это степень многочлена
- ▶ Попробуем обучать модели с разными степенями (как – узнаем потом)
- ▶ Линейный многочлен слишком простой
- ▶ Многочлен большой степени подстраивается под точки обучающей выборки и совсем не похож на реальную функцию



Как контролировать качество

- ▶ Обучая модель, мы стараемся заставить её как можно качественнее решать задачу на тренировочной выборке
- ▶ Для этого формулируется *функционал качества*

$$L = \frac{1}{\ell} \sum_{i=1}^{\ell} \text{err}(x_i)$$

- ▶ Он обозначает насколько сильно текущая модель ошибается на всех обучающих объектах в среднем
- ▶ Для каждой задачи функция err определяется по-своему
- ▶ Например, для бинарной классификации это может быть просто 0, если реальный и предсказанный классы объекта совпали, и 1 – иначе
- ▶ Тогда L будет иметь смысл точности – того, насколько большую долю объектов модель классифицирует неправильно
- ▶ А если посчитаем L на тестовой выборке, то узнаем, насколько хорошо модель классифицирует новые данные!

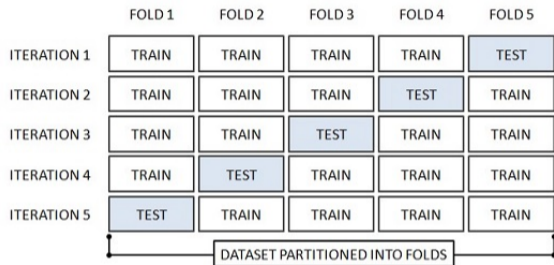
Вот так выглядит переобучение



Кросс-валидация

- ▶ Выбирая в качестве тестовых данных разные объекты выборки, мы можем получить сильно разные значения тестового качества
- ▶ Поэтому при подборе параметров модели используется *кросс-валидация*
- ▶ Самый распространённый вариант такой: все данные случайно разбиваются на несколько частей, дальше каждая часть по-очереди используется в качестве тестовой, а все остальные – в качестве обучения
- ▶ На каждой такой итерации будут получаться свои наилучшие параметры, которые нужно усреднить
- ▶ Средняя ошибка L , посчитанная на кросс-валидации, более устойчива, чем на одном разбиении

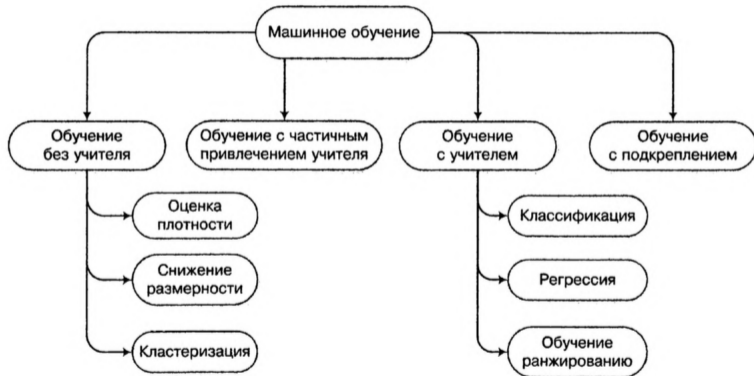
Кросс-валидация



- ▶ Есть проблема, что мы в процессе обучения подстраиваемся под тест
- ▶ Это тоже переобучение
- ▶ Поэтому часто данные делят на три части: обучение, тест и валидация
- ▶ Все описанные операции производятся над валидационными подвыборками
- ▶ Качество на тестовой выборке измеряется в самом конце обучения

Какие ещё бывают типы задач

Задачи машинного обучения не ограничиваются обучением с учителем:



[Ссылка на источник картинки](#)

Итоги занятия

- ▶ Задачи машинного обучения решаются повсюду в современном мире, часто это незаметно для пользователей
- ▶ Для того, чтобы заниматься ML, нужно знать математику и уметь программировать (хоть чуть-чуть)
- ▶ Набор базовых знаний достаточно небольшой, мы сегодня с ним ознакомились и будем закреплять по ходу дальнейшего изучения
- ▶ Одна из основных задач ML – обучение с учителем, где мы по размеченным данным пытаемся предсказывать ответы на новых
- ▶ Для решения задач ML существует много различных подходов и моделей, о которых мы поговорим в следующих лекциях

Успехов!:)